基于分解集成的航空货运需求区间预测研究 *

李 智[1†]，白军成[2]

(1. 兰州交通大学 交通运输学院, 甘肃 730070; 2. 西安电子科技大学 经济管理学院, 西安 710071)

摘 要：航空货运是国家重要的战略资源，在国内及国际间的贸易中扮演着不可或缺的角色。对航空货运需求进行的科学预测是航空公司制定基础设施规划和总体投资决策的重要依据。针对航空货运量数据的不确定性，从实际需求出发，文章引入 Bootstrap 方法进行不确定性估计，提出一种基于分解集成的区间预测方法。具体来说，首先用局部加权回归的时间序列分解(STL)方法将货运需求数据分解，其次由支持向量回归(SVR)和季节自回归综合移动平均(SARIMA)分别对趋势分量与季节分量做预测。再次，创新性地将白噪声分量进行提取并用 Bootstrap 方法做重采样处理。最后，将预测结果与处理后的白噪声进行集成重构，利用分位数构造区间进行不确定性量化。对中国两大枢纽机场货运数据的实验结果表明，构建的区间能够有效地结合预测结果量化不确定性，为区间预测提供了一种新的研究思路。

关键词：分解集成；区间预测；STL；SVR；Bootstrap

中图分类号：TP181;F562 doi: 10.19734/j.issn.1001-3695.2022.02.0059

Research on interval prediction of air cargo demand based on decomposition integration

Li Zhi[1†], Bai Juncheng[2]

(1. *School of Transportation*, *Lanzhou Jiaotong University Gansu* 730070, *China*; 2. *School of Economics & Management*, *Xidian University*, *Xi'an* 710071, *China*)

Abstract: Air cargo is an important strategic resource of country and plays an indispensable role in domestic and international trade. Scientific forecasting of air cargo demand is an important basis for airlines to make infrastructure planning and overall investment decisions. Aiming at the uncertainty of air cargo volume data, this paper introduced Bootstrap method for uncertainty estimation and proposed an interval prediction method based on decomposition integration from the practical needs. Specifically, this paper decomposed the historical data by Seasonal and Trend Decomposition using Loess(STL) method firstly, then forecasted the trend and seasonal components by Support Vector Regression (SVR) and Seasonal Autoregressive Integrated Moving Average (SARIMA) , respectively. Thirdly, this paper extracted and resampled the white noise component by Bootstrap method. Finally, the prediction results were integrated and reconstructed with the processed white noise to quantify uncertainty using quantile construction intervals. The experimental results of cargo data from two hub airports in China show that the constructed interval can effectively quantify the uncertainty in combination with the predicted results, which provides a novel research idea for probabilistic interval prediction.

Key words: decomposition integration; interval prediction; STL; SVR; Bootstrap

0 引言

随着我国经济转向高质量发展阶段，电子商务与快递物流业发展迅速，航空货运需求占货运市场的比重也在逐年增加。科学准确地预测航空货运需求，关注航空货运需求未来的动态趋势，并根据其动态趋势采取相应措施，是航空运输业持续健康发展的有效保障，能够为各级航空运输决策部门制定发展战略和规划提供数据支持[1]。然而，航空货运量数据自身的高噪声、不确定性、非线性和非平稳性特征，使得预测极有挑战性。因此，提出一种稳定、准确的航空货运系统预测模型是一项有价值和关键的任务。

近年来，人们对货运量预测模型进行了大量的研究，主要包括传统预测模型、人工智能预测模型与组合预测模型。传统预测模型，如灰色预测法[2,3]、回归分析法[4]和系统动力学方法[5]，由于其较强的可解释性与对线性数据预测的良好效果，早期在货运需求预测领域得到普遍运用。刘笑佟等人[6]结合不确定理论建立多元线性回归模型预测全国铁路年货运量。张亚男等人[7]构建系统动力学模型，预测 2020—2035 年海口市对外客运需求量。但数据的非平稳性特征使得传统的预测模型很难进行精准建模，平稳序列建模等前提假设则进一步限制了其应用[8]。随着数据挖掘技术的兴起，人工智能方法以其对非线性数据优越的预测性能受到了大量的关注，被广泛应用于各预测领域。邹宗民等人[9]为预测高速公路短时交通流建立支持向量回归模型，结果相较反向传播、自回归移动综合平均模型具有更低的误差。张波等人[10]构建长短期记忆神经网络并应用于机场路面交通拥堵预测，分析认为该模型具有一定实用价值。但是，不管是传统预测模型还是人工智能模型，单一模型都不能充分反映出货运需求的数据特征。为了有效利用各种模型的优点，Bates[11]提出的组合预测思想，受到国内外越来越多研究学者的青睐。赵建立等人[12]构建卷积神经网络结合残差网络的模型对地铁站进出客流量进行预测，研究认为此模型具有比传统模型更好的预测精度。赵亚斌等人[13]建立改进粒子群优化算法与相关向量回归(MPSO-RVM)组合模型进行短期交通流预测研究，通过实验证实了模型对于降噪处理后的数据有较好的预测精度。除了对原始数据直接进行组合预测以外，将数据进行分解集成组合预测也是一个日

收稿日期：2022-02-22；**修回日期：**2022-04-08 **基金项目：**国家自然科学基金资助项目(72161022)；甘肃省自然科学基金项目(20JR5RA394)

作者简介：李智(1996-)，女(通信作者)，河南南阳人，硕士研究生，主要研究方向为数据分析、机器学习、时间序列预测(lizhi1920@163.com)；白军成(1993-)，男，甘肃庆阳人，博士研究生，主要研究方向为机器学习、时间序列预测研究.

益流行的思路。梁小珍等人[14]提出基于奇异谱分析的航空客运分解集成预测模型，选择双优化算法结合支持向量回归模型或自回归移动综合平均模型。结果显示所提出的模型具有良好的预测精度。Li 等人[15]提出基于变分模态分解与经验模态分解的航空货运预测模型，运用自回归移动平均模型与布谷鸟搜索算法优化的 Elman 神经网络进行组合预测，获得了优于基准模型的精度与鲁棒性。由此可见，运用组合预测思想能够集成各个模型的优势，有助于解决模型预测精度不佳的问题。

上述预测方法在本质上属于确定性的点预测，包含的信息有限，难以表征数据的不确定性。为了获得更精确的数据变化信息，减小对管理系统带来的不利影响，区间预测研究逐渐受到重视，并在各领域中得到应用，如风电预测[16,17]，负荷预测[18]，金属价格预测[19]等。Gan 等人[16]利用上下界估计法(LUBE)建立时间卷积网络模型直接输出预测区间并对风速进行预测。除了利用神经网络直接输出区间的 LUBE 方法，在点预测的基础上进一步度量不确定趋势的区间预测是一种流行的方法，如 Wang 等人[17]对点预测产生的误差进行统计研究，提出高斯分布对误差建模，将点预测扩充为区间预测；Serrano-Guerrero 等人[18]将模式识别引入预测，利用数据均值与标准差构造区间对电力负荷进行预测；Wang 等人[19]利用不同分布函数分析数据分布特征，根据点预测结果实现预测区间的构建。

现有文献对货运量预测的研究取得了一系列的成果，但依然存在三个方面的问题：a)针对航空货运需求的预测研究还是停留在对货运需求长期变化的分析[6,7]或是对全国货运量的宏观把握[20]。相比于对全国长期货运量的预测，决策者更需要参考短期货运量的动态信息确定机场总体规划。b)缺少关于货运量的区间预测研究。有效预测货运需求波动区间以制定合理的运输计划，是机场盈利的有效手段，对货运需求波动区间的掌握也可使机场方面提前做好风险应对策略。c)鲜有文献针对数据中的白噪声进行有效处理。白噪声的随机性影响模型处理数据信息的效果，采取有效方式处理白噪声将为模型预测效果带来极大提升。基于以上问题，本文从其他领域中的区间预测方法得到启发，首次提出了一种基于 Bootstrap(BT)方法的航空货运需求区间预测方法，将数据中的白噪声分量剔出，并将其用 Bootstrap 处理后结合组合预测结果构建预测区间(PIs)，以此降低预测难度，提高模型精度，同时量化不确定性。本研究的创新如下：

a) 提出并验证了利用数据本身的白噪声和降噪后数据的预测结果构造预测区间的思想。从统计分析的角度而言，白噪声没有分析价值，因为其不包含任何有用信息，从纯随机的东西中找不到有价值的模式。此外，随机性的数据是不可预测的，将其作为预测对象费时费力，且效果不佳。因此，本预测模型在数据预处理阶段将白噪声剔出，在之后的预测阶段中只预测含有有效信息的分量，降低了预测难度。对于白噪声分量，对其随机打乱处理后与预测结果进行重构，再用分位数构造预测区间。

b) 提出一种区间预测方法。该方法直接生成预测区间，保证了预测的可靠性和稳定性。所提出的区间预测方法不涉及任何现有预测方法所要求的先验知识和预测误差的分布假设，因此比间接区间预测方法具有更好的预测精度。

c) 建立 STL、Bootstrap 和 SVR-SARIMA 组合预测相结合的分解集成模型，实现预测区间的构建。此 STL-SVR-SARIMA-BT 模型在“分而治之”原则的指导下，根据 STL 分解后的趋势分量与季节分量的数据特征，选用合适的模型进行预测，利用各模型的优势，尽可能提取更多的信息，并在此基础上结合利用 Bootstrap 方法处理的白噪声分量构建区间。

1　相关工作

1.1　STL 时间序列分解

局部加权回归的时间序列分解(Seasonal and Trend Decomposition using Loess, STL)方法是一种 k 近邻平滑的非参数回归模型[21]。在迭代过程中，通过迭代学习每个数据点的鲁棒性权值，在微调趋势和周期性方面赋予相对较小的权值，以减少离群值的影响。STL 方法中的局部加权回归过程本质上是一种时间背景下的 k 最近邻核平滑。分解过程允许用户指定趋势和季节成分的变化量，也允许指定周期的长度，这对于分析不同时间分辨率的时间序列是有用的。STL 方法有三个重要参数：N_p--季节周期的观测次数(或长度)；N_s--季节平滑中局部加权回归平滑窗口大小；N_o--外部循环鲁棒性的迭代次数。其他参数可以相应地确定或使用默认设置，如 N_i 是内循环的迭代次数，N_t 是趋势平滑中局部加权回归的平滑窗口大小，N_l 是低通滤波的平滑参数。

在本研究中，使用 STL 分解将航空货运量数据的时间序列分解为趋势分量、季节分量和剩余分量三个部分，减少不同分量间的相互影响，从而使预测结果更加准确。STL 分解结果可以用加法模型表示：

$$Y_t = T_t + S_t + R_t \tag{1}$$

其中，Y_t 为时间的原始时间序列，T_t、S_t、R_t 分别表示趋势分量、季节分量和剩余分量。$T_t + S_t$ 被称为确定性或可预测成分。去掉趋势和季节性分量后，剩余分量中的随机性变得更加明显。

1.2　Ljung-Box 检验(LB 检验)

为了对序列的随机性进行推断，Ljung 与 Box 提出了 LB 检验[22]。构造的统计量 $Q(m)=N(N+2)\sum_{k=1}^{m} r_k^2/(N-k)$，其中 N 是样本总量，r_k 是样本 k 阶滞后的相关系数，该统计量服从自由度为 h 的卡方分布，m 常取 $\ln(N)$。给定显著性水平 α，则拒绝域是 $Q>\chi^2_{1-\alpha,h}$。接受原假设意味着原序列是白噪声序列，否则认为序列存在相关性[23]。LB 检验就是为了验证时间

序列之间有无相关关系的手法。只有那些序列值之间具有密切的相关关系，历史数据对未来的发展有一定影响的序列，才值得挖掘历史数据中的有效信息，用于预测未来的发展[24]。

1.3　SVR 模型

支持向量回归(Support Vector Regression, SVR)[25]是支持向量机在回归领域的一个重要应用，其基本思想是通过非线性映射函数将原始数据样本集映射到高维特征空间 H，并搜索超平面进行线性回归。在接下来的步骤中，将函数以一种减少复杂性的方式尽可能地简化，并在更大范围内进行泛化。假设给定样本为 $\{(x_i,y_i), i=1,2,\dots,n\}$，则回归形式可以表示为

$$y(x)=\omega\phi(x)+b \tag{2}$$

其中，ω 为支持向量，b 为偏移量。

引入松弛变量 ξ_i 和 ξ_i^* 可以较好地解决不确定性，因此支持向量回归可以表示为

$$\begin{cases} \min\limits_{\omega,b,\xi_i,\xi_i^*} \dfrac{1}{2}\|\omega\|^2 + C\sum\limits_{i=1}^{l}(\xi_i-\xi_i^*) \\ s.t. f(x_i)-y_i \le \varepsilon+\xi_i, \\ s.t. y_i - f(x_i) \le \varepsilon+\xi_i^*, \\ \xi_i \ge 0, \xi_i^* \ge 0, i=1,2,\dots,l \end{cases} \tag{3}$$

其中，C 为惩罚因子，ε 为经验误差，C 控制 SVR 模型的经验风险误差。C 越大，对训练过程中误差 ε 越大的样本的惩罚就越大。

1.4　SARIMA 模型

季节自回归综合移动平均(Seasonal Autoregressive Integrated Moving Average, SARIMA)模型是 ARIMA 模型的扩展，用于改进 ARIMA 模型在季节时间序列建模中的性能。

ARIMA 模型是由著名统计学家 Box 和 Jenkins[26]推广的一类线性非平稳时间序列模型。ARIMA 的基本原则是，它假定过去和现在的情况将延续到未来。SARIMA(p, d, q)(P, D, Q)[S]模型共有七个参数，分别是非季节自回归阶数 p，季节自回归阶数 P，公共差分阶数 d，季节差分阶数 D，非季节移动平均阶数 q，季节移动平均阶数 Q，时间序列的周期 S。模型的数学表达式如式(4)所示。

$$a_p(B)A_p(B^s)(1-B)^d(1-B^s)^D Y_t = \theta_0 + e_q(B)E_Q(B^s)r_t \tag{4}$$

其中，$a_p(B)$ 和 $e_q(B)$ 分别为非季节分量中的自回归部分和移动平均部分的 p 阶和 q 阶特征多项式。$A_p(B^s)$ 和 $E_Q(B^s)$ 分别表示季节分量中自回归和移动平均部分的 P 阶和 Q 阶特征多项式。正则和季节差分算子分别为 $(1-B)$ 和 $(1-B^s)$。d 表示不同序列的次数，以消除趋势对序列的影响；D 表示不同序列的次数，以消除季节性对序列的影响。Y_t 为 t 时刻观测值，θ_0 为固定项，r_t 为随机误差。

1.5　Bootstrap 方法

Bootstrap 方法最早由统计学家 Efron 提出[27]。从本质上讲，它是一种基于模拟和替换重采样的非参数数据驱动统计抽样方法，其基本思想是通过对原始样本数据进行有放回地随机抽样，构造自助样本，利用这些自助样本对总体分布进行统计推断。该方法只依赖于给定的原始观测样本数据，不依赖其他假设，能够充分挖掘原始观测样本数据所携带的总体信息，适应性比较广泛，在小样本时表现出的优势更加明显。

一般情况下，每个 Bootstrap 数据集的数据点的数量被重新取样为 N 个，使其与原始数据集的数量相同。所使用的 Bootstrap 的次数 B 常取为 100、500、1000、2000、5000 和 10000，并且已知当 B 增加时，可以准确地估计一个参数。由于计算成本与 B 成比例增加，因此有必要考虑计算机性能和可用时间，使用适当的 B 值。

2　STL-SVR-SARIMA-BT 模型

为实现对于航空货运需求的预测，考虑到其非线性特征，在小样本数据量下构建基于 STL 与 Bootstrap 的区间预测模型。模型可分为四个模块，即数据预处理模块，预测模块，Bootstrap 模块与区间构造模块。实现步骤如下：

步骤 1：数据分解模块。利用 STL 将原始货运数据分解为趋势分量、季节分量和剩余分量。由于不同机场数据间的差异性，对 STL 模型的参数按照数据特性分别设置。

步骤 2：预测模块。根据各分量的特征选择预测模型，以此完善模型选择的合理性。选取能预测非线性特征的 SVR 模型与处理周期性特征效果显著的 SARIMA 模型为组合模型，将分解得到的趋势分量与季节分量的训练集部分作为模型输入，分别训练 SVR 模型与 SARIMA 模型。

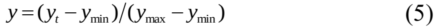
步骤 3：Bootstrap 模块。对剩余分量进行 LB 检验以证明其为白噪声序列后，对其进行 Bootstrap 处理。利用 Bootstrap 的重采样机制对剩余分量随机打乱，通过对过去随机影响延续模拟未来的随机变化。处理后的剩余分量数据分别加到预测得到的趋势和季节分量的总和中，以产生相似的预测矩阵。

步骤 4：区间构造模块。取上述相似预测的值做分位数处理构造区间。由上述模型构成所用方法命名模型为 STL-SVR- SARIMA-BT，模型的具体框架如图 1 所示。

3　实验

3.1　数据集与性能指标

文章选用中国国内两大国际机场--北京机场(S1)与上海机场(S2)的月度货运量作为研究对象，选取 2006 年 1 月至 2020 年 5 月的航空货运数据作为研究样本。以上数据来自统计局数据库(www.stats.gov.cn)与 Wind 数据库(www.wind.com.cn)。文章在预测部分用最大最小归一化法对数据进行处理，归一化公式如下。图 2 与 3 分别是归一化后的两机场月度货运量序列折线图。



$$y = (y_t - y_{min})/(y_{max} - y_{min}) \tag{5}$$

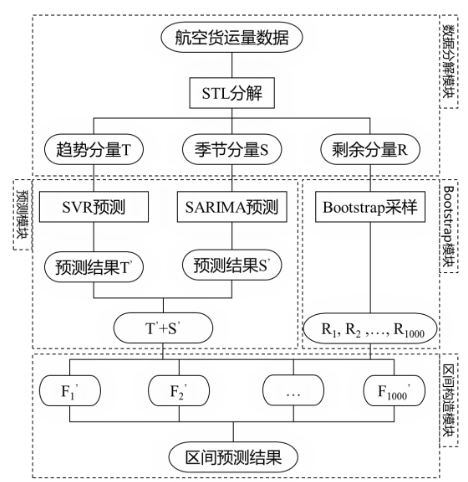


图 1　预测模型框架

Fig. 1　Framework of predictive modelling

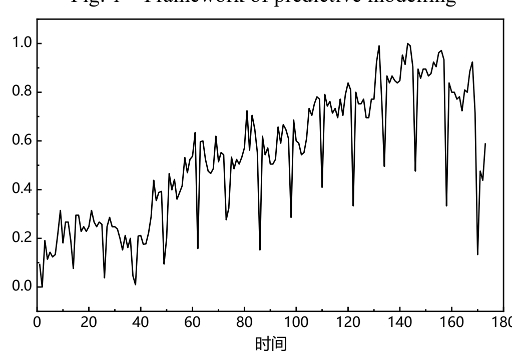


图 2　北京机场月度货运量序列

Fig. 2　Monthly cargo volume series of Beijing airport

由描述性统计(表 1)可知，月度货运量数据呈现出不稳定波动特征。从偏度可看出，两处机场数据的偏度绝对值均大于 0，具有明显的不对称性。此外，数据的峰度均小于 0，说明数据的分布较正态分布更为平坦。

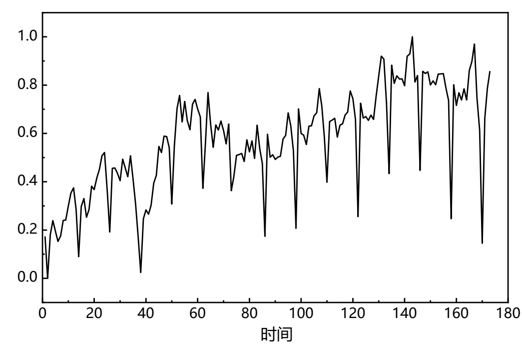


图 3　上海机场月度货运量序列

Fig. 3　Monthly cargo volume series of Shanghai airport

为了定量评估模型预测性能，本文选取三个统计指标：平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方根误差(RMSE)；四个区间评价指标：预测区间覆盖率(PICP)、预测区间平均宽度(PINAW)、平均覆盖率误差指数(ACE)和覆盖宽度准则(CWC)描述各模型性能。具体来说，对于统计指标，MAE 用于直观评价模型预测精度，MAPE 用于描述预测值相比实际值的偏离程度，RMSE 对预测异常值敏感，能够很好地反映出预测的精密度。对于区间评价指标，PICP 用于衡量真实值落在预测区间上下界的比率，PINAW 描述预测

区间的狭窄程度，ACE 反映预测区间与区间名义置信水平(PINC)的偏差，CWC 用于综合评价预测区间的覆盖率与平均宽度。各自的定义如表 2 所示。

对于分量预测的度量，y_t，$\hat{y}_t$ 分别表示 t 时刻的实际值和预测值，其中 $t=1,2,\ldots,N$，N 为样本数。对于预测性能指标，L_t 和 U_t 是预测区间的下界与上界。R 是目标值的宽度，γ 和 η 是决定 PIs 性能的两个超参数。γ 放大了 PICP 的差异，并惩罚无效的 PIs。η 为控制参数，μ 为区间置信水平。值得注意的是，当 PICP 高于预测区间名义置信水平时，PIs 是有效的，因此建议所得区间的 PICP 应大于等于预先确定的名义置信水平值。

将数据样本分别以常见的 70%:30%，75%:25%，80%:20% 的比例划分为训练集与测试集，由预测误差最小原则确定最终划分标准，预测误差结果如表 3，可知将数据样本以 75%:25% 划分所得训练误差均最小，因此将数据样本据此比例划分得训练集样本为 130 个，测试集样本为 43 个。

表 1　机场货运量数据基本统计描述(万吨)

Tab. 1　Basic statistical description of airport cargo volume data (Ten thousand tons)

机场	最小值	最大值	均值	标准差	偏度	峰度
北京	5.6000	16.1000	11.1785	2.7887	-0.1100	-1.1630
上海	15.7200	39.3791	29.1513	5.0830	-0.3980	-0.5080

表 2　评价指标定义

Tab. 2　Definition of evaluation index

指标	定义	表达式
MAE	平均绝对误差	$MAE=\sum_{t=1}^{N}\lvert y_t-\hat{y}_t\rvert/N$
MAPE	平均绝对百分比误差	$MAPE=\sum_{t=1}^{N}\lvert(y_t-\hat{y}_t)/y_t\rvert/N$
RMSE	均方根误差	$RMSE=\sqrt{\sum_{t=1}^{N}(y_t-\hat{y}_t)^2/N}$
PICP	预测区间覆盖率	$PICP=\sum_{t=1}^{N}C_t/N, C_t=\begin{cases}1, y_t\in[L_t,U_t]\\0, y_t\notin[L_t,U_t]\end{cases}$
PINAW	预测区间平均宽度	$PINAW=\sum_{t=1}^{N}(U_t-L_t)/NR$
ACE	平均覆盖率误差指数	$ACE=PICP-PINC$
CWC	覆盖宽度准则	$CWC=PINAW(1+\gamma e^{-\eta(PICP-\mu)}), \gamma=\begin{cases}1, PICP<\mu\\0, PICP\geq\mu\end{cases}$

3.2　原始数据的 STL 分解

STL 分解阶段的目的是将原始数据的噪声序列提取出来。噪声的存在将会降低数据的预测精度、增大预测的难度，而在预测之前将噪声剔出可以对应解决上述问题。文中用试错法确定模型参数，其中北京机场货运量数据对应的参数(N_p,N_i,N_o,N_l,N_t,N_s)为(12,1,5,13,21,17)，上海机场货运量数据对应的参数(N_p,N_i,N_o,N_l,N_t,N_s)为(12,2,0,13,21,17)。对北京、上海两大机场原始的货运量数据分解后所得分量分别如图 4 与 5 所示。可以看出，两处货运量数据均可提取到明显的趋势与季节性。

表 3　数据集划分标准

Tab. 3　Dataset partitioning criteria

数据集划分标准 (训练集:测试集)	MAE S1	MAE S2	MAPE S1	MAPE S2	RMSE S1	RMSE S2
70%:30%	0.0109	0.0048	0.0251	0.0081	0.0151	0.0067
75%:25%	**0.0038**	**0.0026**	**0.0057**	**0.0052**	**0.0046**	**0.0044**
80%:20%	0.0190	0.0321	0.0304	0.0803	0.0238	0.0361

将分解得到的趋势分量，季节分量与剩余分量分别做时间序列平稳性检验(ADF)、自相关函数(ACF)与偏自相关函数(PACF)，分析各分量的平稳性与自相关性。由于篇幅所限，下面仅做结果说明。综合分析结果来看，趋势分量与剩余分量均为平稳性序列，趋势分量、季节分量均存在自相关性。剩余分量的 ACF 与 PACF 可初步表明其不存在自相关性。

接下来，对分解后得到的剩余分量做 LB 检验，进一步判断其是否为白噪声序列。针对两个白噪声序列的 LB 检验结果如图 6、7 所示。

由下图可知，两处机场货运量数据白噪声序列 LB 检验 1-12 阶的值均大于显著水平 0.05，接受白噪声的原假设，即序列均不存在自相关性。基于此，可以说不将剩余分量纳入预测过程，以及用 Bootstrap 打乱剩余分量均有了合理的前提。

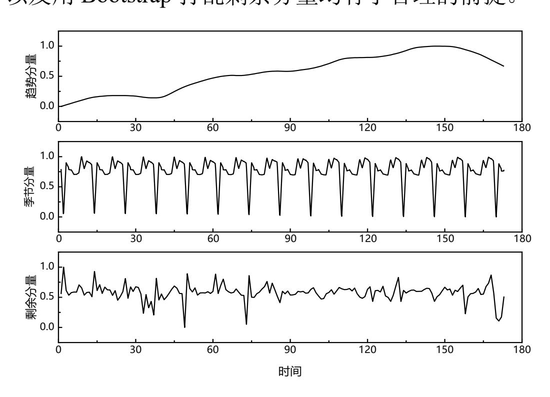


图 4　北京机场货运量的 STL 分解结果

Fig. 4　Decomposition results of Beijing airport cargo volume by STL

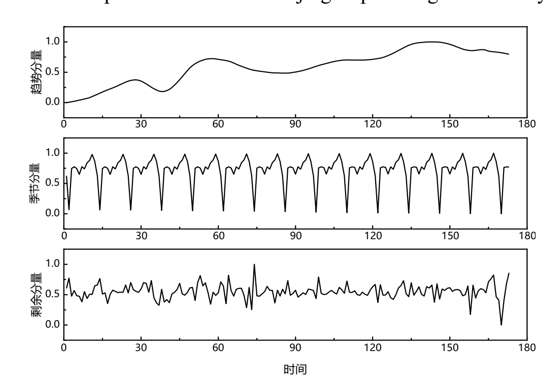


图 5　上海机场货运量的 STL 分解结果

Fig. 5　Decomposition results of Shanghai airport cargo volume by STL

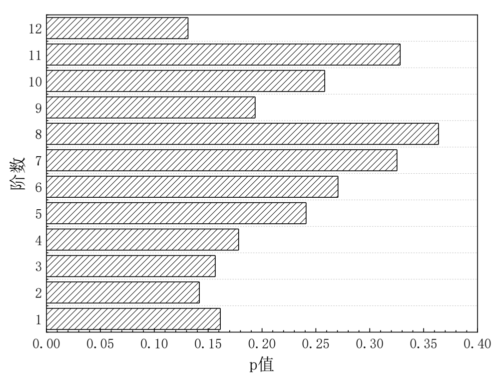


图 6　北京机场白噪声序列 LB 检验结果

Fig. 6　LB test results of Beijing airport white noise sequence

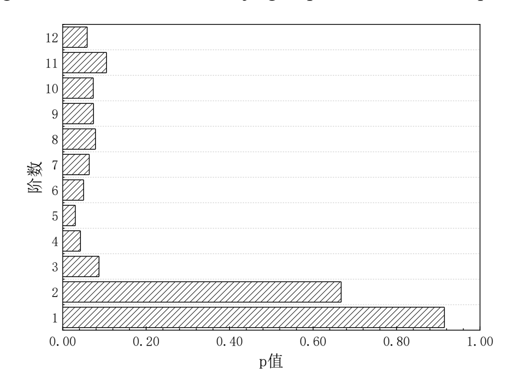


图 7　上海机场白噪声序列 LB 检验结果

Fig. 7　LB test results of Shanghai airport white noise sequence

3.3 SVR-SARIMA 预测

预测阶段只将原始数据的非噪声序列,即趋势分量(T_t)与季节分量(S_t)作为对象，由于剩余分量已被证明是白噪声，将不参与预测过程，而是另行处理。SARIMA 模型的参数设置为：SARIMA(0,1,1)(1,2,0)[12]。模型阶数的设置由最小化信息量准则(Akaike Information Criterion,AIC)[28]与贝叶斯信息准则(Bayesian Information Criterion, BIC)[29]经过多次模型实验所确定。SVR 模型的参数设置为：惩罚因子 C 为 10，经验误差 ε 为 0.01，选用多项式核函数。SVR-SARIMA 模型对北京与上海机场的预测结果如图 8、9 所示。表 4 展示了单模型与组合模型对趋势分量与季节分量的预测效果对比，可以看出 S-S 模型对北京机场与上海机场货运量数据预测的表现均是最优的，其误差均小于两个单模型 SVR 与 SARIMA 的误差，其中 S-S 为 SVR-SARIMA 组合模型的简称。

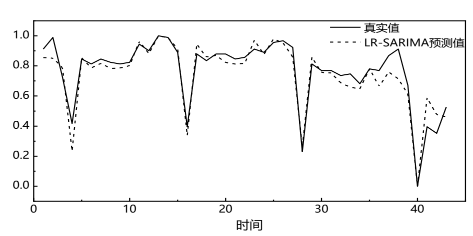


图 8 北京机场预测结果

Fig. 8 Prediction result of Beijing airport

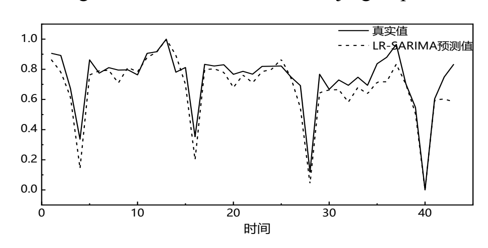


图 9 上海机场预测结果

Fig. 9 Prediction result of Shanghai airport

表 4 趋势分量与季节分量预测效果

Tab. 4 Prediction effect of trend component and seasonal component

分量	MAE		MAPE		RMSE	
	S1	S2	S1	S2	S1	S2
T_t+S_t(SVR)	0.1339	0.0651	0.2451	0.1275	0.1790	0.0819
T_t+S_t(SARIMA)	0.0803	0.0857	0.1046	0.1104	0.1181	0.1077
T_t+S_t(S-S)	**0.0038**	**0.0026**	**0.0057**	**0.0052**	**0.0046**	**0.0044**

3.4 白噪声的 Bootstrap 处理与区间构造

综合考虑处理效率与处理效果，本研究中 Bootstrap 的次数 B 取值 1000。将剩余分量，即数据的白噪声部分随机截取测试集长度，用 Bootstrap 方法随机打乱 1000 次，各得到一个 1000×43 的矩阵。以列为单位对数据进行由小至大的排序，之后各列取选定的分位数(0.80,0.85,0.90,0.95)得出区间的上下界值，从而得到上下界序列。图 10、11 分别显示了北京，上海国际机场货运量区间预测 PINC 为 95%的预测结果。

3.5 对比模型性能分析

为了进一步验证所提模型的有效性，本文建立了一系列对比模型，其按类型可分为针对预测部分、针对噪声处理部分与针对区间构造部分的模型。各对比模型的构造介绍如下：首先，针对趋势分量与季节分量的预测部分，设计选用单一的线性回归(LR)，SARIMA，SVR 模型预测趋势与季节分量，对应模型 1，2，3。其次，针对噪声处理方法，将所提出框架中的 Bootstrap 方法用 Moving Block Bootstrap(MBB)代替，建立 STL-SVR- SARIMA-MBB 模型并记为模型 4。最后，针对整个区间构造部分，将 Wang 等人[17]所提出的以预测误差分布结合点预测结果的区间构造方法应用于本研究对象，建立 STL-SVR- SARIMA-GLS 模型并记为模型 5，本文章所提出的模型 STL-SVR-SARIMA-BT 记为模型 6。模型代号与简称如表 5 所示。为直观体现模型预测效果，对预测区间覆盖率等评价指标作出详细对比，对比结果如表 6、7 所示。

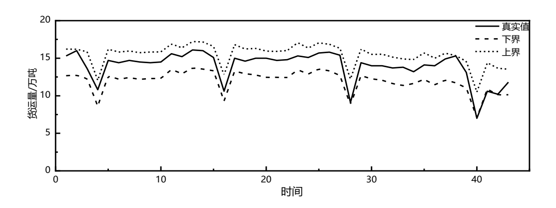


图 10 北京机场货运量区间预测结果

Fig. 10 Forecast results of cargo volume interval of Beijing airport

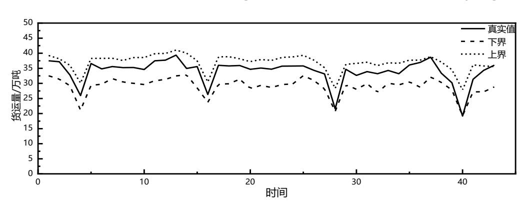


图 11 上海机场货运量区间预测结果

Fig. 11 Forecast results of cargo volume interval of Shanghai airport

表 5 预测模型代号与简称

Tab. 5 Code numbers and abbreviations for prediction models

模型分类	模型代号	模型简称
针对预测部分	模型 1	STL-LR-BT
	模型 2	STL-SARIMA-BT
	模型 3	STL-SVR-BT
针对噪声处理部分	模型 4	STL-SVR-SARIMA-MBB
针对区间构造部分	模型 5	STL-SVR-SARIMA-GLS
所提模型	模型 6	STL-SVR-SARIMA-BT

由表 6、7 可知：a)分解集成组合预测思想在数据预测中有不可替代的作用。货运量数据中包含有多种特征成分，而单一的模型仅能捕捉部分特征。在采用了分解策略的模型中，本文采用基于分解集成的组合预测的方法与其他单一预测模型相比，具有更高的 PICP 值，较窄的 PINAW 值和更小的 CWC 值。以北京机场货运量数据的实验结果为例，在置信水平为 95%条件下，所提出模型的 CWC 值均比模型 1，2，3 减小 99%以上，远远优于对比模型。由此可知，单一模型预测所得区间的 CWC 值居高不下，原因既是未采用“分而治之”策略，侧面印证了组合预测的必要性。b)用 Bootstrap 随机打乱白噪声剩余分量后构造的区间更合理。以上海机场货运量数据的实验结果为例，在置信水平为 80%条件下，模型 6 的 CWC 值比模型 4 小 94.04%。分析结论产生的原因，模型 4 中对白噪声分量做重采样所用的 MBB 方法是根据剩余分量的先后顺序将其划分为可重叠的若干个块，然后有放回地抽取固定长度的块中的所有数据组成新的样本，适合处理存在自相关性的时间序列。考虑到白噪声序列不存在自相关，用 Bootstrap 打乱白噪声序列描述数据中的不确定性，以此模拟未来序列的随机成分更为合理。c)在与最新区间构造方法的比较中，本文方法的 PICP 更接近对应的 PINC，有较窄的 PINAW 与更小的 CWC。一般情况下，较宽的 PINAW 可以获得理想的 PICP，但本文期望 PINAW 尽可能小，而 CWC 可达到 PINAW 和 PICP 间的权衡。由评价指标值可看出所提模型 6 的 CWC 值在各置信水平内均优于或次优于其他模型。也就是说，比起模型 5 基于点预测误差将确定性预测结果扩充为区间，本模型构造区间的方法可得到包含更多观测值且宽度更小的预测区间。d)综合来看，文章提出模型的 PICP 均大于对应的 PINC，即预测区间的概率是满足的。此外，模型的 PINAW 也相对较小，CWC 值在各置信水平中都是最小或次小，这表明提出的 STL-SVR-SARIMA-BT 模型在构造短期货运

需求预测区间方面比其他方法更好。

表 6 区间预测结果评价(北京机场)

Tab. 6 Evaluation of interval prediction results (Beijing airport)

PINC	模型	PICP	PINAW	ACE	CWC
80%	模型 1	0.5116	**0.1571**	-0.2884	2.8714e+5
	模型 2	0.2791	0.1706	-0.5209	3.4983e+10
	模型 3	0.6512	0.1680	-0.1488	286.7808
	模型 4	0.7674	0.1694	-0.0326	1.0321
	模型 5	**0.8605**	0.2176	-0.1395	233.3557
	模型 6	0.8372	0.1605	**0.0372**	**0.1605**
85%	模型 1	0.5581	0.2666	-0.2919	5.8018e+5
	模型 2	0.3256	0.2673	-0.5244	6.5255e+10
	模型 3	0.6977	0.2680	-0.1523	544.5815
	模型 4	0.8140	0.2488	-0.0360	1.7574
	模型 5	0.8605	**0.2429**	-0.1395	260.4901
	模型 6	**0.8605**	0.2669	**0.0105**	**0.2669**
90%	模型 1	0.6279	0.3234	-0.2721	2.6192e+5
	模型 2	0.4884	0.3229	-0.4116	2.8015e+8
	模型 3	0.8140	0.3221	-0.0860	24.1131
	模型 4	0.8837	0.3194	-0.0163	1.0402
	模型 5	0.8837	**0.2783**	-0.1163	93.4993
	模型 6	**0.9070**	0.3238	**0.0070**	**0.3238**
95%	模型 1	0.7209	0.3835	-0.2291	36140.2084
	模型 2	0.8140	0.3857	-0.1360	347.4890
	模型 3	0.8372	0.3824	-0.1128	107.9575
	模型 4	0.9302	0.3771	-0.0198	1.3904
	模型 5	0.9070	**0.3306**	-0.0930	34.9479
	模型 6	**0.9535**	0.3842	**0.0035**	**0.3842**

表 7 区间预测结果评价(上海机场)

Tab. 7 Evaluation of interval prediction results (Shanghai airport)

PINC	模型	PICP	PINAW	ACE	CWC
80%	模型 1	0.5349	0.1588	-0.2651	90717.9190
	模型 2	0.5116	0.1578	-0.2884	2.8837e+5
	模型 3	0.6512	0.1585	-0.1488	270.5045
	模型 4	0.7442	0.1534	-0.0558	2.6532
	模型 5	0.8837	0.2052	-0.1163	68.9394
	模型 6	0.8140	0.1580	0.0140	0.1580
85%	模型 1	0.5581	0.1778	-0.2919	3.8700e+5
	模型 2	0.5581	0.1760	-0.2919	3.8288e+5
	模型 3	0.6977	0.1768	-0.1523	359.2225
	模型 4	0.8605	0.1732	0.0105	0.1732
	模型 5	0.8837	0.2291	-0.1163	76.9557
	模型 6	0.8605	0.1802	0.0105	0.1802
90%	模型 1	0.6512	0.2316	-0.2488	58641.0122
	模型 2	0.6744	0.2310	-0.2256	18280.5976
	模型 3	0.8372	0.2381	-0.0628	5.7372
	模型 4	0.9070	0.2524	0.0070	0.2524
	模型 5	0.9302	0.2625	-0.0698	8.8542
	模型 6	0.9070	0.2372	0.0070	0.2372
95%	模型 1	0.7209	0.3620	-0.2291	34113.3438
	模型 2	0.8372	0.3746	-0.1128	105.7606
	模型 3	0.8837	0.3783	-0.0663	10.7793
	模型 4	0.9302	0.3654	-0.0198	1.3470
	模型 5	0.9302	0.3118	-0.0698	10.5177
	模型 6	0.9535	0.3899	0.0035	0.3899

4 结束语

针对航空货运需求预测中的不确定性问题，本文建立 STL- SVR-SARIMA-BT 分解集成组合模型，对机场货运需求进行预测，同时引入多种预测模型作为基准模型进行对比分析，提供了一种构造区间的方法。模型的核心思想是将数据中的白噪声剔出后预测数据余下包含有效信息的部分，针对剔出的白噪声序列用 Bootstrap 随机打乱后与预测结果重构，利用分位数构造区间预测结果。

通过对中国两处机场货运量的预测实验可以发现：①应根据数据特点，选择适合的预测模型。通过对航空货运需求的预测来看，SARIMA 模型在季节分量预测中取得了比 SVR 更好的效果。针对结构比较简单的时间序列数据，SVR 能得到较好的效果。②相比于采用单一的预测模型预测各个分量，采用多种预测模型分别预测相应的分量，充分利用不同预测模型的优势，可以获得更好的预测效果。SVR-SARIMA 模型有效地降低了单一模型对于复杂数据拟合能力的不足，在预测分析中能较好地预测数据，优于单一的 SVR，SARIMA 模型，且在预测方面比传统机器学习中的支持向量机更有效。③将白噪声分量从原始数据中剔出可明显减轻数据预测难度，提高预测精度。多数原始数据中均包含有不可预测的白噪声即随机项，将白噪声分量剔出即可得到含有有效信息的分量，此时再进行预测便不受随机项的干扰。综上所述，所建立的模型具有较好的准确性、鲁棒性和操作上的简单性，可以为区间预测提供新的思路。此外，鉴于所提出模型在预测精度和稳定度两方面的优势，其未来在周期性数据预测等方向将有广阔的应用前景。

参考文献：

[1] 文军，蒋由辉，方文清. 航空货运量的优化组合预测模型 [J]. 计算机工程与应用，2010, 46 (15): 215-217, 229. (Wen Jun, Jiang Youhui, Fang Wenqing. Optimal combination forecasting model of air cargo volume [J]. Computer Engineering and Applications, 2010, 46 (15): 215-217, 229.)

[2] 徐莉，薛锋. 基于 GM (1, 1) 残差二次修正的铁路货运量预测 [J]. 交通运输工程与信息学报，2019, 17 (02): 44-50. (Xu Li, Xue Feng. Prediction of rail freight volume of China based on secondary residual error modification of GM (1, 1) model [J]. Journal of Transportation Engineering and Information, 2019, 17 (02): 44-50.)

[3] 崔乃丹，向万里，孟学雷，等. 基于小波灰色 GM (1, 1) 模型的货运量预测研究 [J]. 铁道科学与工程学报，2017, 14 (11): 2480-2486. (Cui Naidan, Xiang Wanli, Meng Xuelei, *et al.* Railway freight volume forecasting based on grey GM (1, 1) model and wavelet de-noising [J]. Journal of Railway Science and Engineering, 2017, 14 (11): 2480-2486.)

[4] 游士兵，严研. 逐步回归分析法及其应用 [J]. 统计与决策，2017 (14): 31-35. (You Shibing, Yan Yan. Stepwise regression analysis and its application [J]. Statistics and Decision, 2017 (14): 31-35.)

[5] 刘菁，赵静云. 基于系统动力学的建筑碳排放预测研究 [J]. 科技管理研究，2018, 38 (09): 219-226. (Liu Jing, Zhao Jingyun. Building carbon emissions prediction research based on system dynamics [J]. Science and Technology Management Research, 2018, 38 (09): 219-226.)

[6] 刘笑佟，任爽. 基于不确定理论的铁路货运需求预测 [J]. 运筹与管理，2020, 29 (03): 135-141. (Liu Xiaotong, Ren Shuang. Railway freight demand forecast based on uncertainty theory [J]. Operations Research and Management Science, 2020, 29 (03): 135-141.)

[7] 张亚男，席洋，杨嘉钰，等. 海南自贸港背景下海口市对外客运量预测研究 [J]. 交通运输系统工程与信息，2021, 21 (03): 260-267, 281. (Zhang Yanan, Xi Yang, Yang Jiayu, *et al.* Forecast of Haikou external passenger volume considering free trade port in Hainan province [J]. Journal of Transportation Systems Engineering and Information Technology, 2021, 21 (03): 260-267, 281.)

[8] 耿晶晶，刘玉敏，李洋，等. 基于 CNN-LSTM 的股票指数预测模型 [J]. 统计与决策, 2021, 37 (05): 134-138. (Geng Jingjing, Liu Yumin, Li Yang, *et al.* Stock index prediction model based on CNN-LSTM [J]. Statistics and Decision, 2021, 37 (05): 134-138.)

[9] 邹宗民，郝龙，李全杰，等. 基于粒子群优化-支持向量回归的高速公路短时交通流预测 [J]. 科学技术与工程, 2021, 21 (12): 5118-5123. (Zou Zongmin, Hao Long, Li Quanjie, *et al.* Short-term traffic flow prediction of expressway based on particle swarm optimization-support vector regression [J]. Science Technology and Engineering, 2021, 21 (12): 5118-5123.)

[10] 张波，周芳，李强. 基于 LSTM 模型的北京首都国际机场路面交通拥堵预测 [J]. 数理统计与管理, 2020, 39 (05): 761-770. (Zhang Bo, Zhou Fang, Li Qiang. Traffic delay index forecast of Beijing capital international airport based on LSTM model [J]. Journal of Applied Statistics and Management, 2020, 39 (05): 761-770.)

[11] Bates J M, GRANGER C, W J. The combination of forecasts [J]. Operational Research Quarterly, 1969, 20 (1): 451-468.

[12] 赵建立，石敬诗，孙秋霞，等. 基于混合深度学习的地铁站进出客流量短时预测 [J]. 交通运输系统工程与信息, 2020, 20 (05): 128-134. (Zhao Jianli, Shi Jingshi, Sun Qiuxia, *et al.* Short-time inflow and outflow prediction of metro stations based on hybrid deep learning [J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20 (05): 128-134.)

[13] 赵亚斌，白璘，武奇生，等. 基于 MPSO-RVM 的短期交通流预测方法研究 [J]. 计算机应用研究, 2020, 37 (S1): 69-71. (Zhao Yabin, Bai Lin, Wu Qisheng, *et al.* Research on short-term traffic flow prediction method based on MPSO-RVM [J]. Application Research of Computers, 2020, 37 (S1): 69-71.)

[14] 梁小珍，郭战坤，张倩文，等. 基于奇异谱分析的航空客运需求分析与分解集成预测模型 [J]. 系统工程理论与实践, 2020, 40 (07): 1844-1855. (Liang Xiaozhen, Guo Zhankun, Zhang Qianwen, *et al.* An analysis and decomposition ensemble prediction model for air passenger demand based on singular spectrum analysis [J]. Systems Engineering-Theory & Practice, 2020, 40 (07): 1844-1855.)

[15] Li Hongtao, Bai Juncheng, Cui Xiang, *et al.* A new secondary decomposition-ensemble approach with cuckoo search optimization for air cargo forecasting [J]. Applied Soft Computing Journal, 2020, 2020 (90): 106161.

[16] Gan Zhenhao, Li Chaoshun, Zhou Jianzhong, *et al.* Temporal convolutional networks interval prediction model for wind speed forecasting [J]. Electric Power Systems Research, 2021, 191: 106865.

[17] Wang Jianzhou, Niu Tong, Lu Haiyan, *et al.* A novel framework of reservoir computing for deterministic and probabilistic wind power forecasting [J]. IEEE Transactions on Sustainable Energy, 2020, 11 (1): 337-349.

[18] Serrano Guerrero X, Briceño León M, Clairand J M, *et al.* A new interval prediction methodology for short-term electric load forecasting based on pattern recognition [J]. Applied Energy, 2021, 297: 117173.

[19] Wang Jianzhou, Niu Xinsong, Zhang Linyue, *et al.* Point and interval prediction for non-ferrous metals based on a hybrid prediction framework [J]. Resources Policy, 2021, 73: 102222.

[20] 徐玉萍，邓俊翔，蒋泽华. 基于组合预测模型的铁路货运量预测研究 [J]. 铁道科学与工程学报, 2021, 18 (01): 243-249. (Xu Yuping, Deng Junxiang, Jiang Zehua. Railway freight volume forecasting based on a combined model [J]. Journal of Railway Science and Engineering, 2021, 18 (01): 243-249.)

[21] Cleveland W S. Robust locally weighted regression and smoothing scatterplots [J]. Journal of the American Statistical Association, 1979, 74 (368): 829-836.

[22] Ljung G M, Box G E P. On a measure of lack of fit in time series models [J] Biometrika, 1978, 65 (2): 297-303.

[23] 徐萧，李勇. 绿色债券市场收益率溢出效应研究 [J]. 时代金融, 2018 (35): 170-171, 175. (Xu Xiao, Li Yong. Study on yield spillover effect of green bond market [J]. Times Finance, 2018 (35): 170-171, 175.)

[24] 王珂. 石油期货价格带时变跳跃强度的 GARCH 建模及对汇率影响的统计分析 [D]. 南京: 南京师范大学, 2020. (Wang Ke. GARCH modeling of oil futures price with time-varying jump intensity and statistical analysis of its influence on exchange rate [D]. Nanjing: Nanjing Normal University, 2020.)

[25] Chen Wusi, Hasanipanah M, Nikafshan Rad H, *et al.* A new design of evolutionary hybrid optimization of SVR model in predicting the blast-induced ground vibration [J]. Engineering with Computers, 2019, 37 (2): 1455-1471.

[26] Box G E P, Jenkins G M, Reinsel G C, *et al.* Time series analysis: forecasting and control [M]. 5th ed. John Wiley & Sons, 2015.

[27] 赵远，杨琳. 基于 Bootstrap 理论的小子样寿命评估模型 [J]. 北京航空航天大学学报, 2022, 48 (01): 106-112. (Zhao Yuan, Yang Lin. Lifetime evaluation model of small sample based on Bootstrap theory [J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 48 (01): 106-112.)

[28] Alger J R, Minhajuddin A, Dean Sherry A, *et al.* Analysis of steady-state carbon tracer experiments using akaike information criteria [J]. Metabolomics, 2021, 17 (7): 1-15.

[29] Shinotsuka H, Nagata K, Yoshikawa H, *et al.* Development of spectral decomposition based on Bayesian information criterion with estimation of confidence interval [J]. Science and technology of advanced materials, 2020, 21 (1): 402-419.